LLM iz perspektive studenata

Marija Gaurina | 15 svibnja, 2026

Sažetak: Ovaj članak nastavak je pilot istraživanja iste autorice i suradnika, a istražuje percepcije i iskustva studenata prve godine Sveučilišta u Splitu o primjeni velikih jezičnih modela (LLM-ova) u učenju na sveučilišnoj razini. Na temelju podataka fokus-skupine analiziraju se njihovi obrasci korištenja, razina povjerenja, uočene prednosti i nedostaci te percepcija pouzdanosti LLM-ova u rješavanju zadataka. Studenti ističu praktičnost alata i mogućnost brzog pristupa objašnjenjima, ali naglašavaju i probleme s netočnim odgovorima, pogrešnim interpretacijama i prevelikim oslanjanjem na modele. Rezultati ukazuju na potrebu za razvojem akademske UI pismenosti, pedagoškim smjernicama i nadzorom kako bi se smanjile zablude i osiguralo odgovorno korištenje ovih tehnologija u ranoj fazi studiranja.

LLM-ovi u učenju

Pojava velikih jezičnih modela (LLM – *Large Language Models*) poput GPT-4, GPT-4.1, GPT-5, Geminija, Claudea, Microsoft Copilota otvorila je nove mogućnosti u obrazovanju, od personaliziranog učenja do automatizirane podrške studentima. LLM-ovi omogućuju brzu izradu materijala, provjeru znanja, davanje objašnjenja i izradu primjera, što korisnicima daje osjećaj učinkovitosti i lakoće učenja. Prema istraživanjima, studenti aktivno i sve češće koriste alate poput ChatGPT-a u svakodnevnom učenju, većinom kao podršku pri rješavanju zadataka, pripremi ispita i izradi sažetaka (Gabbay i Cohen, 2024; Huang i Li, 2023; Jalilova i Musayeva, 2025). Umjetna inteligencija može pridonijeti konceptualnom razumijevanju i omogućiti personalizirano učenje, potičući interakciju i procese učenja koje su usklađene s individualnim potrebama (Kasneci i sur., 2023; Keat i sur., 2024; Peláez-Sánchez i sur., 2024). Zabilježeno je i poboljšanje samostalnog učenja te razvoj interdisciplinarnog promišljanja jer LLM-ovi olakšavaju povezivanje sadržaja iz različitih područja (Keat i sur., 2024). Uz brojne prednosti, studenti se susreću i s problemima poput povremenih netočnosti koje mogu narušiti povjerenje u sustav (Wang i sur., 2024), a uočen je i niz tehničkih, etičkih i pedagoških izazova (Kasneci i sur., 2023). LLM-ovi su ograničeni podacima na kojima su trenirani i mogu davati izmišljene, ali uvjerljive odgovore (Xu i sur., 2024). Zbog toga je nužno istražiti kako studenti, kao jedna od ranjivijih skupina korisnika u obrazovnom sustavu, koriste i interpretiraju informacije dobivene putem LLM-ova te koje im kompetencije nedostaju.

Ovaj članak kao nastavak pilot istraživanja iz 2025. ima za cilj analizirati iskustva studenata prve godine Sveučilišta u Splitu u korištenju LLM-ova, pri čemu se kvalitativna analiza temelji na fokus-skupini. S obzirom na to da ove tehnologije snažno utječu na obrazovne prakse i akademske navike, razumijevanje studentskih stavova predstavlja ključan element u planiranju daljnje integracije umjetne inteligencije u visoko obrazovanje.

Kako je provedeno istraživanje?

U studenom 2025. provedena je kvalitativna studija koja se temeljila na fokus-skupini sa studentima prve godine različitih studijskih programa Sveučilišta u Splitu. Svi sudionici prethodno su pohađali istu srednju školu u Sinju, što omogućuje relativno homogen kontekst i usporediva prethodna obrazovna iskustva. Fokus-skupina provedena je *online* te je trajala jedan sat. Sudionicima su unaprijed poslani primjeri odgovora koje LLM-ovi generiraju pri rješavanju zadataka iz fizike kako bi se rasprava mogla temeljiti na konkretnim i prepoznatljivim situacijama. Ukupno je sudjelovalo šest studenata. Voditeljica je postavljala polustrukturirana pitanja o njihovim navikama korištenja LLM-ova, procjenama kvalitete dobivenih odgovora i osvrtima na iskustva tijekom pripreme za kolegije. S obzirom na opseg i karakter, istraživanje se smatra pilot istraživanjem koje služi kao temelj za planiranje obuhvatnije glavne studije. S obzirom na povjerljivost podataka, imena studenata nisu evidentirana, nego su se odgovori bilježili u obliku S1 - S6. Sastanak u kojem se odvijala rasprava

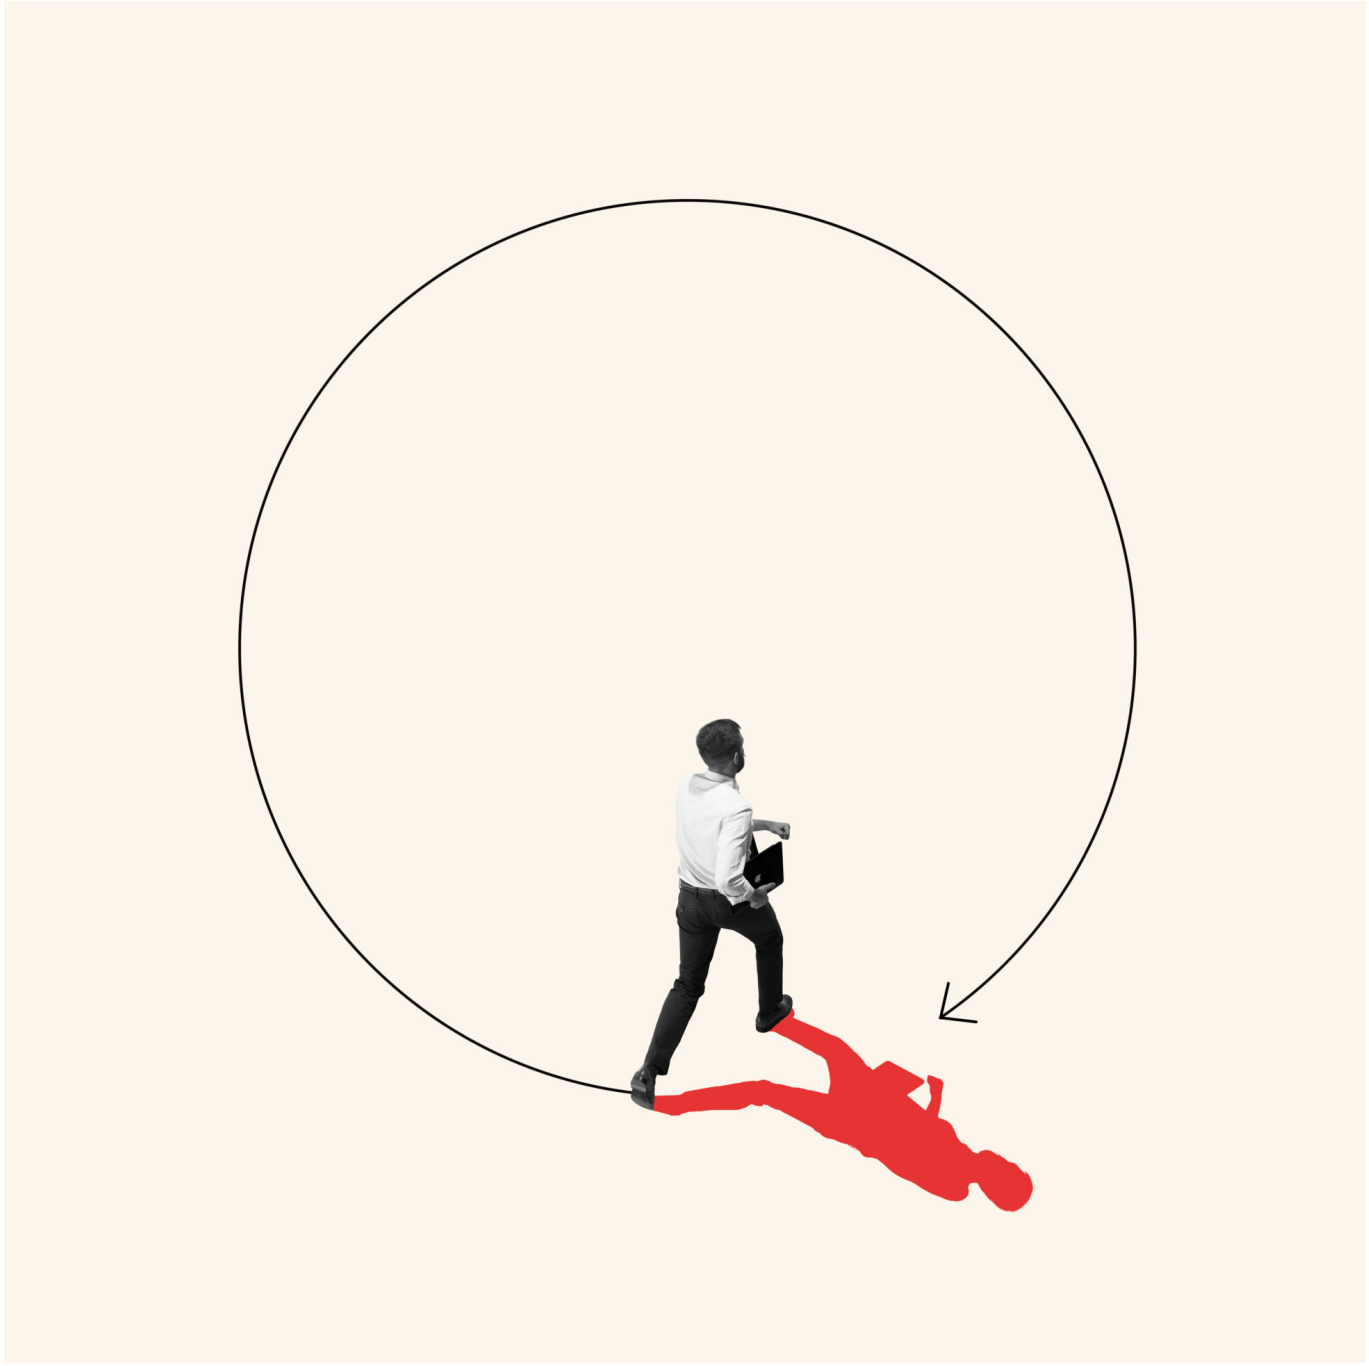
sniman je te potom analiziran. Analiza je provedena ručno, tematskim pristupom, s ciljem identifikacije glavnih obrazaca razmišljanja i iskustava studenata.

Što kažu studenti?

Svi studenti izjavili su da redovito koriste LLM-ove, najčešće ChatGPT i Perplexity AI, osobito tijekom prvog semestra, kada se suočavaju sa složenim matematičko-fizikalnim sadržajima. Najčešće ih koriste za dobivanje pojašnjenja teško razumljivih pojmova, izradu kratkih bilješki, rješavanje fizikalnih zadataka i zadataka strukovnih usmjerenja poput elektrotehnike, provjeru vlastitih rješenja te generiranje novih primjera zadataka. Jedan student opisao je svoj način korištenja: „Kad učim, prvo pokušam sam riješiti zadatak, a onda ga dam modelu da vidim jesam li dobro razumio postupak.“ (S1) Nekoliko studenata priznalo je da ponekad koriste modele kako bi „brzo riješili zadatak“, osobito kada zaostaju ili imaju poteškoća s matematičkim dijelom gradiva.

Studenti su istakli niz prednosti. Najčešće spominju dostupnost objašnjenja i komentiraju: „profesor ne može biti dostupan 24/7“ (S2), te pojednostavljivanje složenih pojmova, pri čemu modeli često nude jednostavnija i studentima primjerenija objašnjenja nego udžbenici. Mogućnost učenja vlastitim tempom i postavljanja neograničenog broja pitanja također se navodi kao velika korist, kao i samoprovjera dobivenih rješenja, posebno iz područja mehanike i elektromagnetizma. Nekima modeli povećavaju motivaciju jer „kada znaju da im alat može pomoći, lakše se upuste u zadatak“.

Unatoč prednostima, studenti su uočili ponavljajuće probleme. Brzo su uočili netočna matematička rješenja. Modeli često preskaču korake, pogrešno manipuliraju jednadžbama ili daju brojčane rezultate bez dosljednog postupka. Jedan student je rekao: „Izgleda lijepo napisano, ali kad izračunam sam, brojčano ispadne krivo.“ (S4) Velik problem predstavljaju i grafički prikazi, jer modeli često ne mogu očitati vrijednosti s grafa ili iz slikovnih prikaza. Studenti su istaknuli: „Ako opišem graf u tekstu, nekad nešto pogodi, ali kad pošaljem sliku, gotovo je.“ (S2) Preuvjerljiv ton modela dodatno vara studente, jer pogreške ponekad zvuče potpuno uvjerljivo: „Najgore je kad sve izgleda logično, a skroz je krivo.“ (S5) Također su primijetili neusklađenost s terminologijom i oznakama koje koriste kroz kolegije: modeli koriste drugačije oznake, što rješenja čini neprepoznatljivima profesorima, a što onda kod profesora izaziva sumnju. To se podudara s opažanjima nastavnika u sličnim situacijama, gdje se prema neobičnim oznakama moglo zaključiti da je rješenje generirao LLM (Lišnić i Gaurina, 2025). Etika korištenja i mogućnost razvoja ovisnosti o alatima pojavile su se kao važna tema. Većina studenata tvrdi da LLM-ove koristi kao pomoćni alat, ali nekoliko ih je priznalo da ih povremeno koriste i u situacijama kada bi trebali samostalno rješavati zadatak. „Iskreno, kad nemam vremena, pustim njega da riješi. Znam da nije dobro, ali…“ (S3) Studenti su svjesni rizika, ali procjenjuju da im modeli „mogu pomoći samo do određene granice“ jer su ispiti složeni tako da zahtijevaju dubinsko razumijevanje. Percepcija korisnosti LLM-ova u učenju elektrotehnike i fizike je pozitivna, ali uz jasnu dozu opreza. Studenti naglašavaju da je LLM koristan kao asistent, ali ne i kao zamjena za učenje. Rješenja treba provjeriti ručno, osobito brojčana, a navode da modeli najbolje rade kada student već poznaje osnovne koncepte. Jedan je student zaključio: „Ako ne znaš fiziku ili elektrotehniku, LLM ti neće pomoći, ali ako kontaš, pomoći će ti puno.” (S2)



Pomoć ili zamka?

Dobiveni rezultati ukazuju na visok stupanj prihvaćenosti LLM-ova među studentima prve godine Sveučilišta u Splitu. Korištenje je intenzivno, učestalo i usmjereno na širok spektar, od stvaranja bilješki do rješavanja problemskih zadataka. Studenti jasno razlikuju korisnost modela u kontekstu učenja, ali priznaju da njihova uporaba ponekad vodi do pasivnog usvajanja sadržaja. To je u skladu s istraživanjima koja upozoravaju da LLM-ovi mogu poticati površno učenje ako se ne koristi kritički pristup (Kasneci i sur., 2023; Xu i sur., 2024).

Analiza podataka sugerira da glavni izazovi uključuju neprepoznate pogreške LLM-a, prenaglašeno povjerenje studenata u generirane odgovore i nedostatak sistematiziranog razvoja UI pismenosti. Simboličke pogreške i pogrešne interpretacije zadataka, koje su naglašavali i nastavnici (Lišnić i Gaurina, 2025), pojavljuju se i u iskustvima studenata, što ukazuje na stabilan obrazac teškoća u STEM područjima pri korištenju LLM-ova.

Istodobno, rezultati potvrđuju da studenti vide potencijal LLM-ova kao dodatnog alata za učenje,

osobito kada traže strukturirano objašnjenje ili pomoć u organiziranju gradiva. Pri tome naglašavaju važnost postojanja minimalnog predznanja, što je u skladu s navodima da LLM-ovi ne mogu zamijeniti temeljno razumijevanje pojmova (Kasneci i sur., 2023; Xu i sur., 2024).

Što dalje?

Studija provedena među studentima prve godine Sveučilišta u Splitu pokazuje da su oni aktivni korisnici velikih jezičnih modela i da jasno prepoznaju njihove prednosti u svakodnevnom učenju. Međutim, rezultati istodobno naglašavaju potrebu za sustavnim razvojem UI pismenosti i kritičkog promišljanja, budući da prekomjerno oslanjanje na modele može dovesti do površnog razumijevanja gradiva i prenošenja pogrešaka u rješavanju zadataka. S obzirom na to da su svi sudionici ove studije prethodno završili srednju školu u Sinju, njihova iskustva dodatno upućuju na važnost uvođenja ranog obrazovanja o umjetnoj inteligenciji već na srednjoškolskoj razini, kako bi studenti u visoko obrazovanje dolazili s razvijenijim kompetencijama u radu s UI alatima. Ovo istraživanje ima obilježja pilot studije jer je provedeno na malom uzorku i poslužilo je za preliminarno ispitivanje obrazaca uporabe LLM-ova među studentima te identificiranje ključnih izazova i potreba za daljnjim istraživanjem. Na temelju dobivenih uvida može se preporučiti da glavna studija obuhvati veći i raznolikiji uzorak studenata različitih studijskih programa te kombinira anketne metode, analizu stvarnih studentskih radova i eksperimentalne zadatke rješavane uz i bez pomoći LLM-ova. Na taj bi se način mogla utvrditi povezanost između razine AI pismenosti, načina korištenja modela i stvarnih obrazovnih ishoda. Integracija AI alata u visoko obrazovanje mora biti popraćena jasnim pedagoškim smjernicama koje naglašavaju provjeru izvora, razumijevanje dobivenih rješenja i odgovorno korištenje tehnologije kako bi se ostvarila maksimalna obrazovna korist, uz minimalne rizike.